



# CTSCAFE PARA CIUDADANOS.....

<http://www.ctscafe.pe>

ISSN 2521-8093



**REVISTA DE INVESTIGACIÓN MULTIDISCIPLINARIA**



<http://www.ctscafe.pe>

Volumen VIII- N° 24 Noviembre 2024

ISSN 2521-8093



## Desarrollo de un modelo de Inteligencia Artificial para la mitigación de arvenses dañinos con detección de malezas

Sr. Dylan Ricardo Pineda Sandoval  
Universidad Surcolombiana  
Correo Electrónico: u20202192371@usco.edu.co

Sr. Daniel Santiago Vargas Monje  
Universidad Surcolombiana  
Correo Electrónico: u20202191528@usco.edu.co

Recibido: 03 Septiembre 2024  
Aceptado: 02 Noviembre 2024

**Resumen:** El control de arvenses representa entre el 20% y el 30% de los costos de mano de obra en cultivos agrícolas, siendo una práctica crucial pero poco estudiada. Las arvenses no solo compiten con los cultivos por recursos esenciales como agua, luz y nutrientes, sino que también sirven de hospederas para plagas y enfermedades, reduciendo significativamente el rendimiento y la calidad de la cosecha. En Colombia, se han identificado cerca de 170 especies de arvenses en cafetales, afectando gravemente cultivos como café, arroz, soja y algodón. Este estudio propone el uso de Roboflow y YOLO-NAS para optimizar la identificación y manejo de arvenses mediante técnicas de visión artificial. Se comparan varios modelos de inteligencia artificial, evaluando su precisión, tiempo de entrenamiento y capacidad de generalización. Los resultados muestran que, aunque YOLO-NAS supera a Roboflow 3.0 en términos de precisión y eficiencia, Roboflow ofrece una integración más sencilla y configuraciones para usuarios menos experimentados.

**Palabras claves:** Control de arvenses/ Visión artificial/ Roboflow/ YOLO-NAS/ Agricultura/ Detección de objetos/ Inteligencia artificial.

**Abstract:** Weed control represents between 20% and 30% of labor costs in agricultural crops, being a crucial but understudied practice. Weeds not only compete with crops for essential resources such as water, light, and nutrients but also serve as hosts for pests and diseases, significantly reducing yield and crop quality. In Colombia, around 170 weed species have been identified in coffee plantations, severely affecting crops such as coffee, rice, soybeans, and cotton. This study proposes the use of Roboflow and YOLO-NAS to optimize the identification and management of weeds through advanced computer vision techniques. Several artificial intelligence models are compared, evaluating their accuracy, training time, and generalization capability. The results show that while YOLO-NAS outperforms Roboflow 3.0 in terms of accuracy and efficiency, Roboflow offers easier integration and predefined settings beneficial for less experienced users.

**Keywords:** Weed control/ Computer vision/ Roboflow/ YOLO-NAS/ Agriculture/ Object detection/ Artificial intelligence.

**Résumé :** Le désherbage représente entre 20 % et 30 % des coûts de main d'œuvre dans les cultures agricoles, étant une pratique cruciale mais peu étudiée. Les mauvaises herbes non seulement rivalisent avec les cultures pour les ressources essentielles telles que l'eau, la lumière et les nutriments, mais elles servent également d'hôtes aux ravageurs et aux maladies, réduisant considérablement le rendement et la qualité de la récolte. En Colombie, près de 170 espèces de mauvaises herbes ont été identifiées dans les plantations de café, affectant gravement les cultures comme le café, le riz, le soja et le coton. Cette étude propose l'utilisation de Roboflow et YOLO-NAS pour optimiser l'identification et la gestion des mauvaises herbes à l'aide de techniques de vision par ordinateur. Plusieurs modèles d'intelligence artificielle sont comparés, évaluant leur précision, leur temps de formation et leur capacité de généralisation. Les résultats montrent que bien que YOLO-NAS surpasse Roboflow 3.0 en termes de précision et d'efficacité, Roboflow offre une intégration et des configurations plus faciles pour les utilisateurs moins expérimentés.

**Mots-clés:** Désherbage/ Vision artificielle/ Roboflow/ YOLO-NAS/ Agriculture/ Détection d'objets/ Intelligence artificielle.

## 1. Introducción

80

El manejo de arvenses es una de las prácticas más costosas y cruciales dentro del manejo sanitario en los cultivos agrícolas, representando entre el 20% y el 30% de los costos en mano de obra. A pesar de su importancia, existen pocos estudios sobre su manejo y las pérdidas que causan en el rendimiento final del cultivo. Las arvenses, también conocidas como malezas, malas hierbas, hierbas invasoras o yuyos, son plantas no deseadas que compiten con los cultivos por agua, luz, espacio y nutrientes. Además, pueden hospedar insectos, plagas, hongos y nematodos, lo que agrava los problemas fitosanitarios y reduce la calidad y cantidad de las cosechas.

En Colombia, se han identificado cerca de 170 especies de arvenses en cafetales, siendo las familias Gramineae, Compositae, Euphorbiaceae, Amaranthaceae y Rubiaceae las más representadas. Algunos cultivos como el café, arroz, soja y algodón son extremadamente sensibles a la interferencia de las arvenses, con pérdidas de rendimiento de hasta el 66.5%. Este trabajo propone la utilización de Roboflow y YOLO-NAS para el desarrollo de un sistema de visión artificial capaz de identificar y manejar arvenses en diversos cultivos de manera eficiente. Roboflow es una plataforma diseñada para facilitar el desarrollo de modelos de visión artificial, proporcionando herramientas para la anotación y preprocesamiento de datos, así como para el entrenamiento y despliegue de modelos. La versión 3.0 de Roboflow ofrece mejoras significativas en la interfaz de usuario, capacidades de preprocesamiento y aumento de datos, soporte para múltiples frameworks y una mejor colaboración en equipo. Por su parte, YOLO-NAS es una versión avanzada de la familia de modelos YOLO, optimizada mediante técnicas de Neural Architecture Search (NAS) para mejorar la precisión y eficiencia en la detección de objetos.

## 2. Material y métodos

Durante la primera fase del proyecto, se llevara a cabo la definición del problema y objetivos identificando el problema definiendo claramente la tarea de visión en artificial (detección de objetos), también se establecerán los objetivos definiendo las métricas de rendimiento clave tales como (precisión, recall, F1-Score, tiempo de inferencia, consumo de recursos, etc). En la segunda fase se hará la recolección y preparación de la data, se obtendrá un conjunto de datos representativo y adecuado para la tarea, estos datos cubrirán diversas condiciones y escenarios relevantes, También se le realizará limpieza de datos, etiquetado y aumento en la data (data augmentation), esto debe ser dividido en subconjuntos de entrenamiento tales como validación y prueba.

También se hará una selección inicial de todos los modelos preentrenados y frameworks populares como YOLO, SSD, Faster R-CNN, EfficientDet, entre otros. Revisando la literatura y estudios previos para identificar que modelo de visión artificial que han tenido éxito en tareas similares. Después de esto se hace la configuración del entorno de desarrollo para utilizar los frameworks necesarios, se debe asegurar la disponibilidad de hardware adecuado, como GPUs o TPUs, para entrenamiento y evaluación de los modelos.

Luego se entrenará cada modelo candidato utilizando el conjunto de datos de entrenamiento, se configurarán técnicas de optimización y ajuste de hiperparámetros (grid search, random search, Bayesian optimization) todo esto para mejorar el rendimiento y realizar comparaciones de cada uno de los modelos, esto se hará evaluando el rendimiento de cada modelo en el conjunto de validación, volviendo a ajustar los hiperparámetros y realizando mejoras iterativas basadas en los resultados de evaluación.

Por último se hace la evaluación y comparación de los modelos en donde se evalúa el desempeño utilizando el conjunto de pruebas para evaluar de manera objetiva el rendimiento de cada uno, calculando métricas de rendimientos clave: mAP, recall, F-1 Score, etc y analizando el tiempo de inferencia y el consumo de recursos. En base a esto se selecciona el modelo que muestra el mejor equilibrio entre las métricas de rendimiento y cumpla con los requisitos del sistema, todo este enfoque sistemático asegura que la selección del modelo de visión artificial se basa en una evaluación objetiva y detallada, maximizando las posibilidades de elegir el modelo más adecuado para las necesidades específicas del proyecto.

## 3. Resultados

En este estudio, se compararon varios modelos de inteligencia artificial para la tarea de detección de objetos. Los modelos evaluados mencionados previamente. El objetivo principal es determinar cuál de estos modelos ofrece el mejor rendimiento en términos de precisión, tiempo de entrenamiento, y capacidad de generalización.

Se evidenciaron variedad de comportamientos en cada uno de los modelos en distintas variables como el tiempo de entrenamiento, precisión.

## Resultados generales

**Tabla N° 1:** Tabla Comparativa resultados

	<b>1er Modelo</b>	<b>2do Modelo</b>	<b>3er Modelo</b>
<b>Model type:</b>	<b>Roboflow 3.0 O.D</b>	<b>YOLO-NAS O.D</b>	<b>Roboflow 3.0 O.D</b>
Epochs	147	147	40
mAP	91.3%	89.3%	91.0%
Precision	91.5%	87.1%	91.7%
Recall	88.7%	88.2%	88.0%
Images	11363	11363	11363
Train	9362	9362	9362
Valid	1335	1335	1335
Test	666	666	666
Preprocessing	Auto-Orient Resize 640x 640	Auto – Orient Resize: 640x640	Auto – Orient Resize: 640x640
Augmentations	Crop: 0% Minimum Zoom, 24% Maximum Zoom	Flip: Horizontal Crop: 0% Minimum Zoom, 24% Maximum Zoom Blur: Up to 2.4px	Flip: Horizontal Crop: 0% Minimum Zoom, 24% Maximum Zoom Blur: Up to 2.4px
Tiempo entrenamiento	8:02 Horas	41:13 Horas	1:11 Horas

Fuente: Elaboración propia

**Tabla N° 2:** Análisis Comparativo

<b>YOLO-NAS</b>	<b>ROBOFLOW3.0</b>
Superó a Roboflow 3.0 en términos de precisión y eficiencia de inferencia (FPS), lo que lo hace más adecuado para aplicaciones en tiempo real.	Aunque ligeramente más lento en entrenamiento e inferencia, ofrece una integración más sencilla y ajustes preconfigurados que pueden ser beneficiosos para usuarios que buscan facilidad de uso

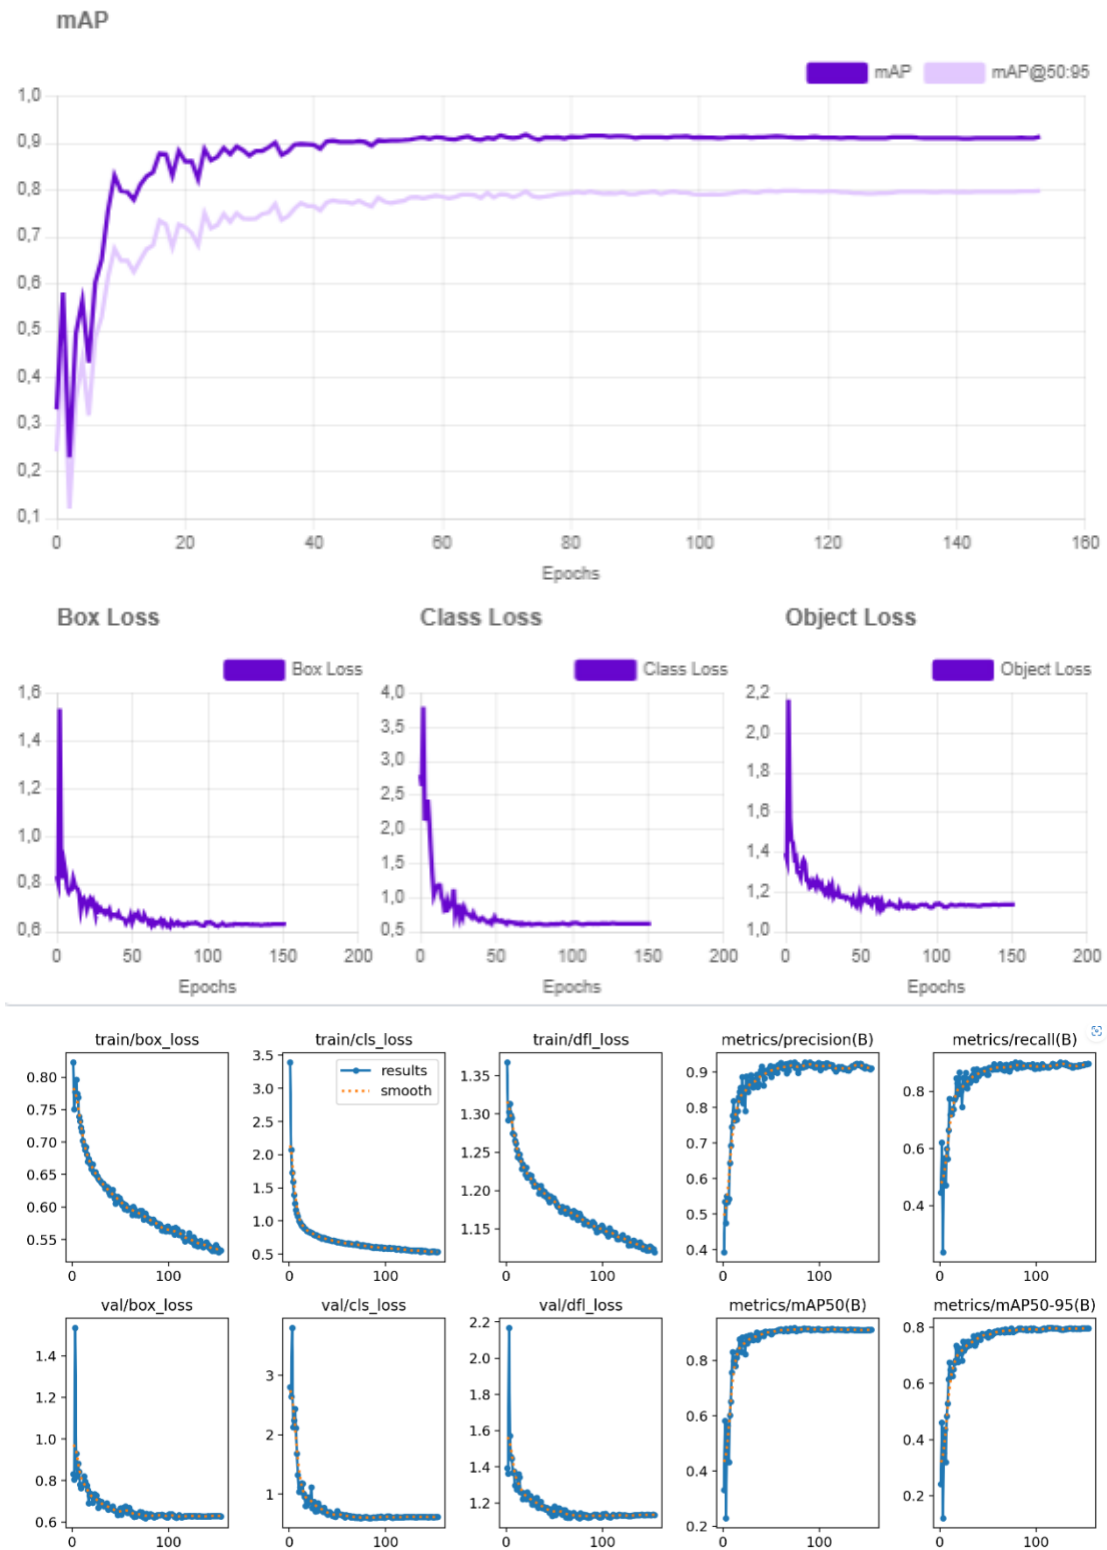
Fuente: Elaboración propia

## Resultados gráficos

### Gráfico general


A continuación, se mostrarán las gráficas resultantes de los 3 modelos en relación mAP-Epochs y también los resultados de las métricas obtenidas en cada uno de los modelos

### Modelo N°1

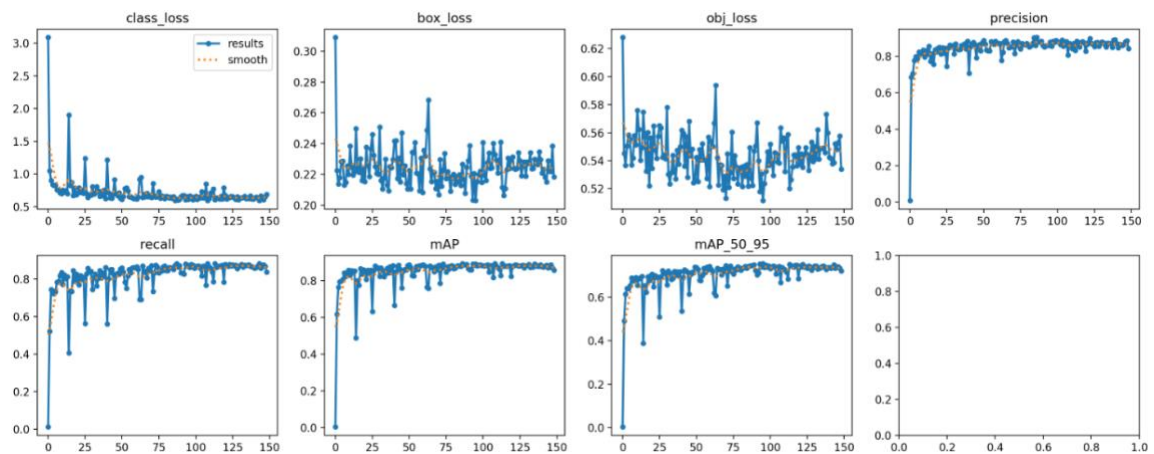


Fuente: Elaboración propia

### Modelo N°2



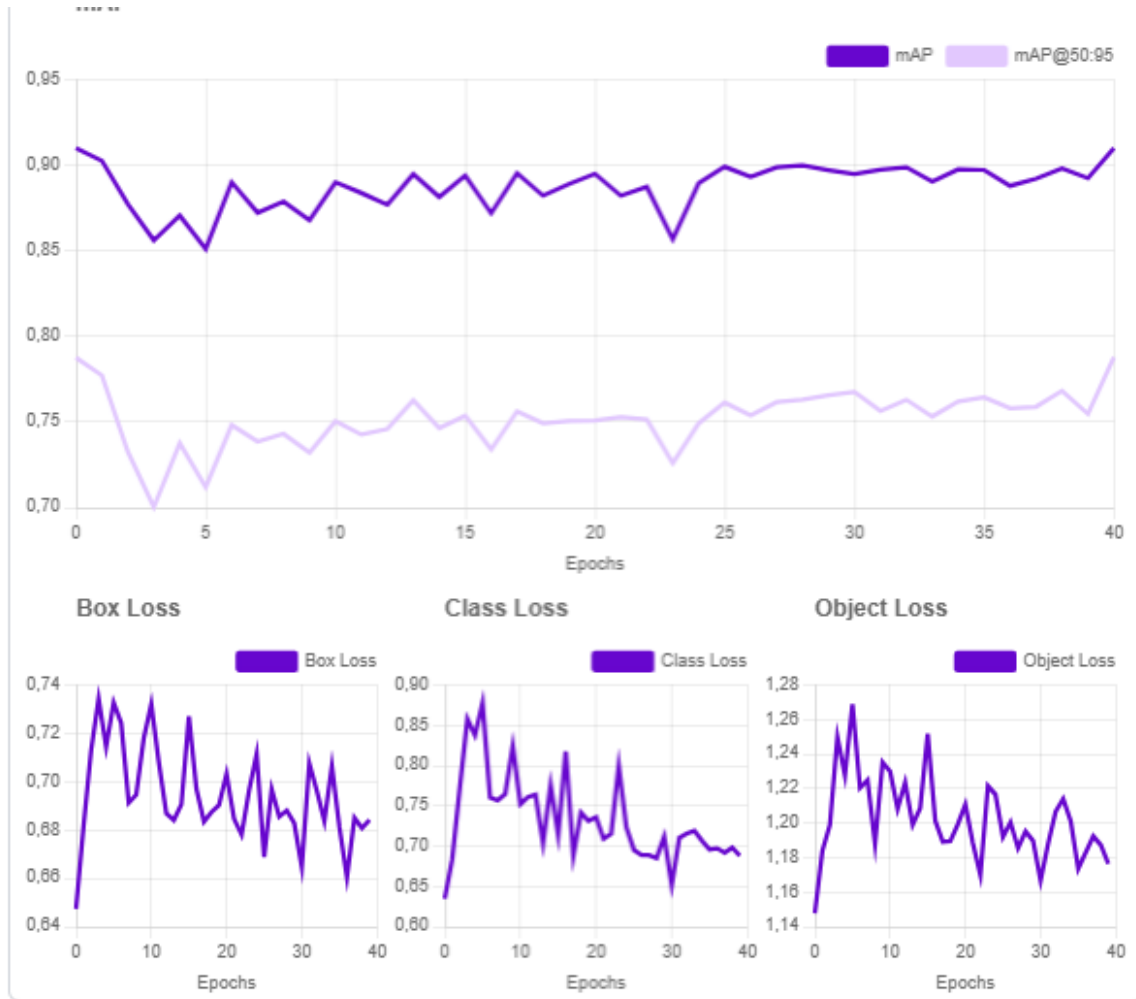
84



Fuente: Elaboración propia



### Modelo N°3



Fuente: Elaboración propia

## Gráficos Validation and set test Modelo N° 1

### -Validation

Validation Set    Test Set    Training Graphs


#### Average Precision by Class



Fuente: Elaboración propia

### -Set

#### Average Precision by Class

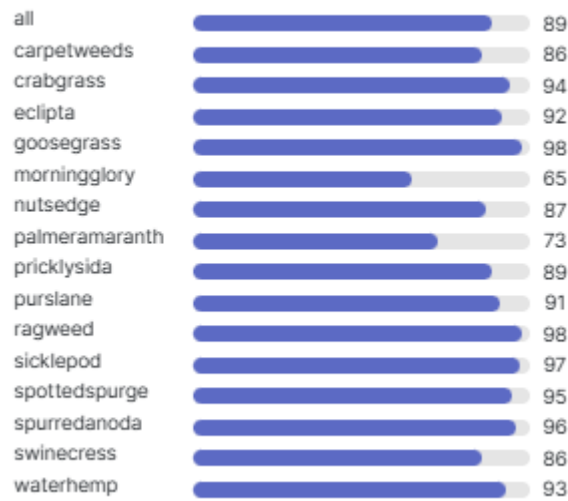


Fuente: Elaboración propia

## Modelo N°2

### -Validation

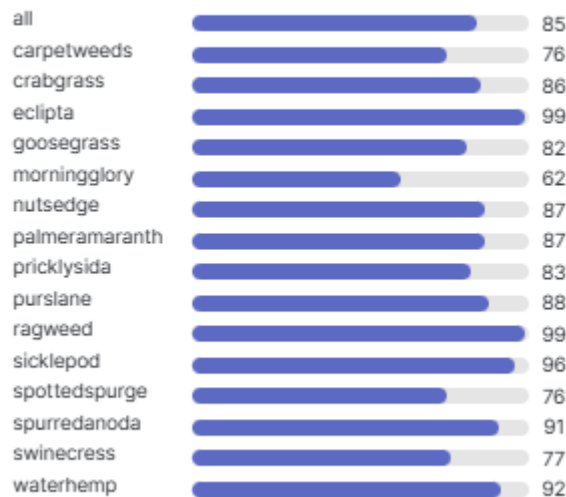
#### Average Precision by Class



Fuente: Elaboración propia

### -Set

#### Average Precision by Class



Fuente: Elaboración propia

### Modelo N° 3

#### -Validation

#### Average Precision by Class




Fuente: Elaboración propia

88

#### -Set

#### Average Precision by Class



Fuente: Elaboración propia

### Prueba a modelos

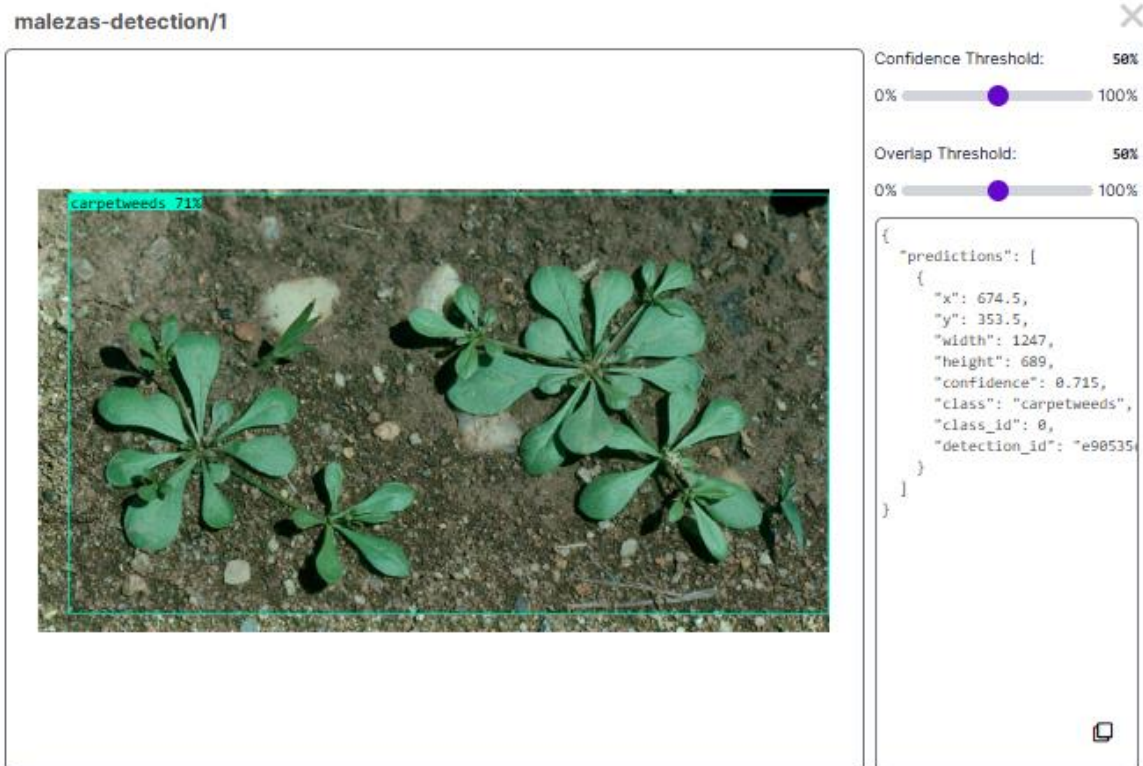
Imagen N°1: Imagen de prueba



Fuente: Elaboración propia

Imagen N°2: Primer modelo

malezas-detection/1



Confidence Threshold: 50%  
0% 100%

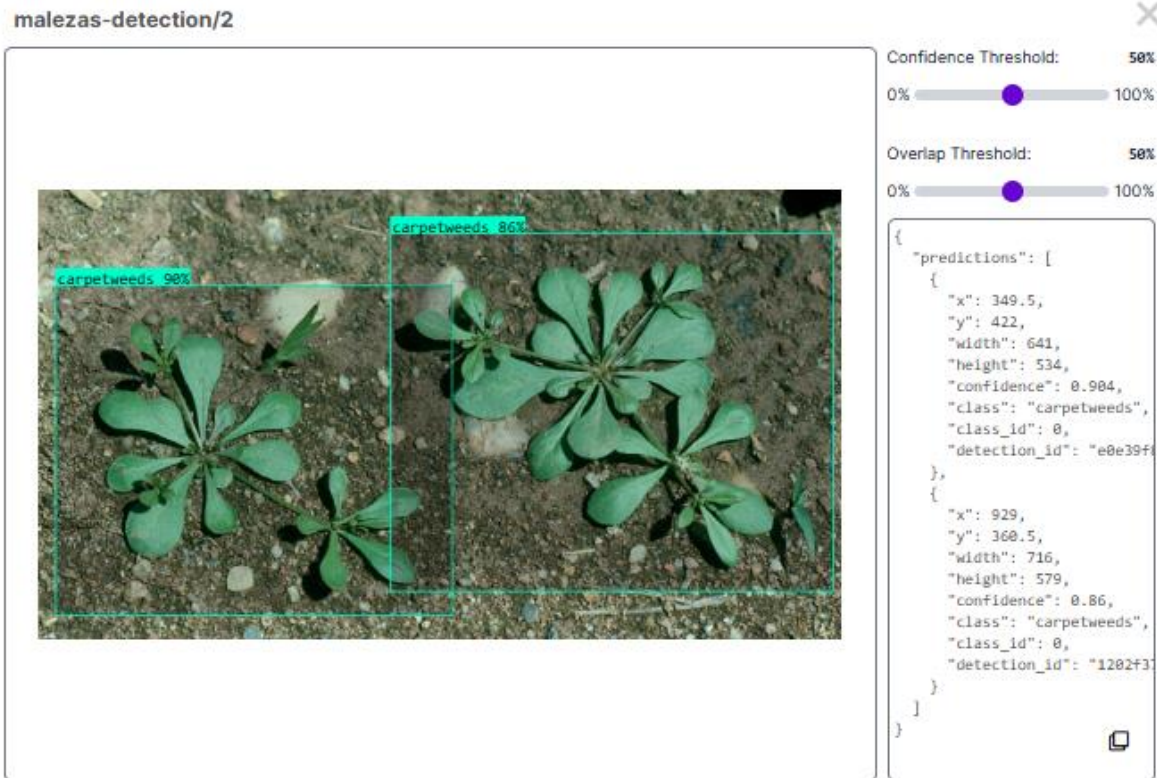
Overlap Threshold: 50%  
0% 100%

```
{  
  "predictions": [  
    {  
      "x": 674.5,  
      "y": 353.5,  
      "width": 1247,  
      "height": 689,  
      "confidence": 0.715,  
      "class": "carpetweeds",  
      "class_id": 0,  
      "detection_id": "e90535"  
    }  
  ]  
}
```

Fuente: Elaboración propia

### Imagen N°3: Segundo modelo

malezas-detection/2



Confidence Threshold: 50%  
0% 100%

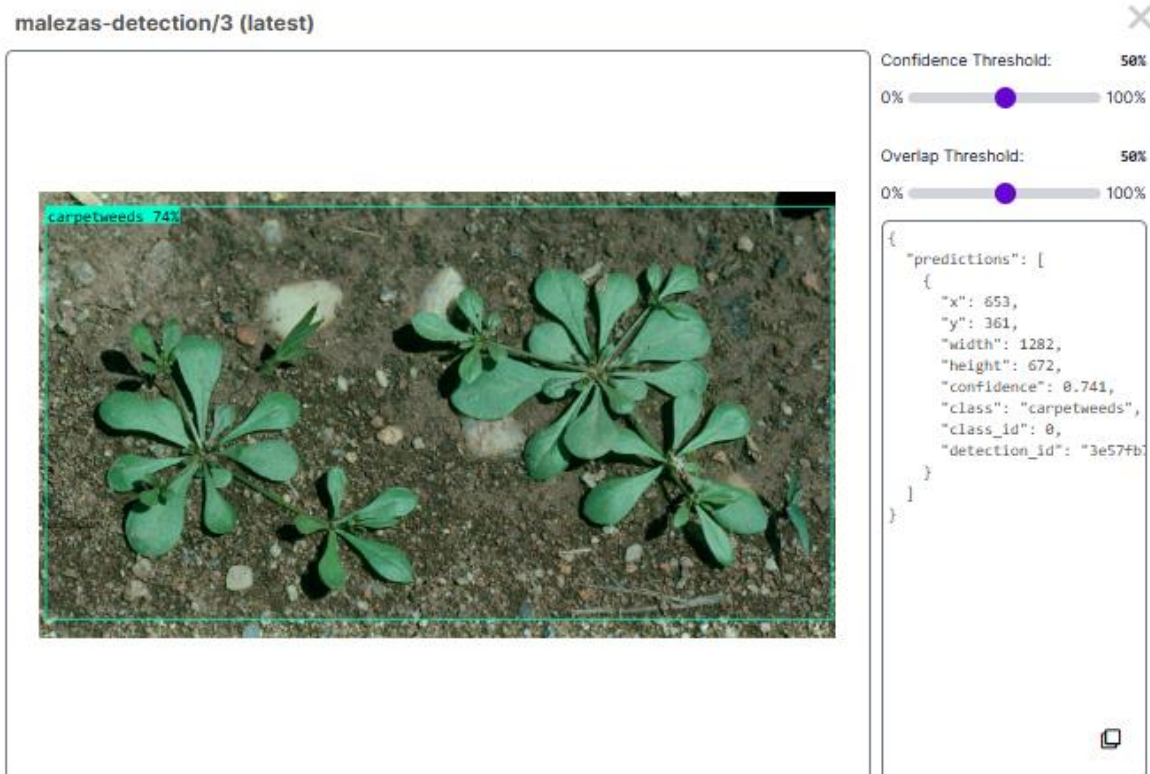
Overlap Threshold: 50%  
0% 100%

```
{  
  "predictions": [  
    {  
      "x": 349.5,  
      "y": 422,  
      "width": 641,  
      "height": 534,  
      "confidence": 0.984,  
      "class": "carpetweeds",  
      "class_id": 0,  
      "detection_id": "e0e39f4"  
    },  
    {  
      "x": 929,  
      "y": 360.5,  
      "width": 716,  
      "height": 579,  
      "confidence": 0.86,  
      "class": "carpetweeds",  
      "class_id": 0,  
      "detection_id": "1202f3"  
    }  
  ]  
}
```

Fuente: Elaboración propia

### Imagen N°4: Tercer modelo

malezas-detection/3 (latest)



Confidence Threshold: 50%  
0% 100%

Overlap Threshold: 50%  
0% 100%

```
{  
  "predictions": [  
    {  
      "x": 653,  
      "y": 361,  
      "width": 1282,  
      "height": 672,  
      "confidence": 0.741,  
      "class": "carpetweeds",  
      "class_id": 0,  
      "detection_id": "3e57fb"  
    }  
  ]  
}
```

Fuente: Elaboración propia

#### 4. Conclusiones

En conclusión, el modelo #1 demostró ser el más eficaz para la tarea de detección de objetos, logrando una precisión de 91.3 % y una precisión de 91.5%. Aunque el modelo #2 tuvo un tiempo de entrenamiento más tardío, su rendimiento general fue inferior en comparación al resto. El modelo tiene mejor segmentación que los otros 2, indica que el modelo YOLO-NAS es efectivo para aplicaciones que requieren alta precisión y eficiencia en tiempo real. Por otro lado, Roboflow 3.0 destaca por su facilidad de uso y capacidades de integración, lo que lo hace adecuado para desarrolladores que buscan una implementación rápida y sencilla.

##### Trabajos Futuros

El presente estudio abre múltiples avenidas para futuras investigaciones y desarrollos. Entre los trabajos futuros, se destacan:

- Ampliación del Dataset: Incrementar la cantidad y diversidad de imágenes anotadas de arvenses para mejorar la generalización de los modelos.
- Integración con drones y robots agrícolas: Implementar el sistema de visión artificial en drones y robots agrícolas para el monitoreo automatizado de campos y la aplicación de herbicidas de precisión.
- Desarrollo de modelos híbridos: Explorar la combinación de YOLO-NAS con otros modelos de Deep-learning para aprovechar las fortalezas de diferentes arquitecturas y mejorar aún más la precisión y eficiencia.

#### 5. Literatura citada

**Ó. de J. Córdoba** (2022). “Plantas arvenses” 2022.

**L. Fernando and S. G. E. Hincapié** “L Capítulo 5”.

**L. F. Salazar-Gutiérrez** (2020). “Weeds from the coffee zone of Colombia”. Cenicafé, 2020

**C. Marcelo, P. Javier, P. Gastón, F. S. Francisco, L. Gerardo, and C. Mauricio**  
“Detección en Tiempo Real de Malezas a través de Técnicas de Visión Artificial”.

**L. Leon and C. Campos** (2024). “(PDF) Detección de malezas en cultivos utilizando inteligencia artificial”. (Accessed: May 28, 2024) [Online]. Available: [https://www.researchgate.net/publication/359879057\\_Deteccion\\_de\\_malezas\\_en\\_cultivos\\_utilizando\\_inteligencia\\_artificial](https://www.researchgate.net/publication/359879057_Deteccion_de_malezas_en_cultivos_utilizando_inteligencia_artificial)

**REVISTA DE INVESTIGACIÓN MULTIDISCIPLINARIA**



<http://www.ctscafe.pe>

Volumen VIII- N° 24 Noviembre 2024

*Contáctenos en nuestro correo electrónico  
[revistactscafe@ctscafe.pe](mailto:revistactscafe@ctscafe.pe)*

Página Web:  
<http://ctscafe.pe>

217

